Iranian Journal of curriculum studies

ISSN: 1735-4986
https://www.jcsicsa.ir

Design and Validation of an Intelligent Model for Personalizing Specialized Learning Paths in Curriculum Studies Based on the Decision Tree Algorithm

Najma Asghari [1], Javad Hatami [*2], Farhad Seraji [3], Esmaeil Azimi-Yancheshmeh[4]

1. PhD Student in Curriculum Planning, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University. asghari.najma13886@gmail.com
2. ***Corresponding author*** Full Professor, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University. j.hatami@modares.ac.ir

3. Full Professor, Department of Curriculum Development and Instruction Methods, Faculty of Psychology and Education, University of Tehran, Tehran, Iran. Email: fseraji@ut.ac.ir

4. Associate Professor, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University. e.azimi@modares.ac.ir, Scopus Author ID: 57095821900

Article Info

Article type:
Research Article

Keywords: Personalized Learning, Curriculum Studies, Artificial Intelligence, Decision Tree Algorithm, Specialized Learning Paths

Article history:
Received: 02 June 2026
Reviewed: 19 August 2026
Accepted: 29 August 2026

ABSTRACT

Given the diversity of sub-disciplines in curriculum studies, personalizing learning paths is an undeniable necessity. This study aimed to design and validate an intelligent model based on the decision tree algorithm to systematize specialized learning paths. This applied research utilized a mixed-methods approach. In the qualitative phase, indicators were identified using the fuzzy Delphi method with a panel of 8 experts. In the quantitative phase, data from 45 doctoral students were collected via stratified random sampling, and the Classification and Regression Trees (CART) algorithm was trained. Twenty-two indicators across individual, cognitive, and professional categories were confirmed. The model extracted 65 transparent decision rules, identifying "time management" as the root node. Evaluations demonstrated high efficiency, achieving an average overall accuracy of 0.98 and an F1-score of 0.97, which statistically outperformed competing algorithms. The highly interpretable decision tree model is an effective tool for academic and career counseling. Integrating this model as a module in learning management systems is recommended to provide dynamic and targeted educational recommendations.

Citation (APA): Asghari, N., Hatami, J., Seraji, F., & Azimi, E. (2026). Design and Validation of an Intelligent Model for Personalizing Specialized Learning Paths in Curriculum Studies Based on the Decision Tree Algorithm. **Iranian Journal of Curriculum Studies.** 21 (81), 227-250 https://doi.org/ 10.22034/jcs.2026.584738.2599

© The Author (s). Publisher: Iranian Curriculum Studies Association.

Extended Abstract

Introduction

The sustainable development of societies is deeply intertwined with the cultivation of a specialized and creative workforce. Curriculum Studies, as a core academic discipline in educational sciences, is a dynamic and multidimensional field encompassing a broad spectrum of subjects, from macro-level policy-making to workplace training. Due to organizational demands and labor market necessities, various sub-disciplines within curriculum studies have emerged, transforming the field into a highly professional one. Consequently, students require specialized, tailored learning paths to shape their professional identities effectively. However, current evidence suggests that a significant portion of postgraduate students lack the foundational cross-occupational skills required in the field, as university curricula are often confined to theoretical discussions and a uniform approach. The rapid advancement of educational technologies and the emergence of machine learning algorithms provide a substantial opportunity to address this gap. Among various artificial intelligence algorithms, the "Decision Tree" stands out due to its high interpretability and optimal performance in classification tasks. Therefore, this study aimed to design and validate an intelligent model based on the decision tree algorithm to personalize specialized learning paths for curriculum studies students.

Methodology

This study employed an applied, mixed-methods (qualitative-quantitative) approach. In the qualitative phase, the objective was to identify and validate the factors influencing the personalization of learning paths. A two-round Fuzzy Delphi method was conducted with a panel of 8 experts in curriculum planning and artificial intelligence. The fuzzy outputs were defuzzified, and variables with a weight above the 0.7 threshold were retained. In the quantitative phase, the statistical population comprised doctoral students in curriculum studies across Iranian universities. A sample of 45 students was selected using stratified random sampling, based on their professional fields (public education, higher education, and workplace). The primary data collection instrument was a researcher-made structured questionnaire consisting of 9 main components and 22 indicators, possessing high content validity (CVI > 0.79) and internal reliability (Cronbach's alpha = 0.89). For the machine learning modeling, the Classification and Regression Trees (CART) algorithm was utilized. The target variables (labels) were defined as three distinct professional paths. To prevent overfitting and ensure the robustness of the model, a 5-fold cross-validation technique was applied to the entire dataset. Hyperparameters were fine-tuned using the Gini impurity criterion, a maximum depth of 5, and a minimum samples split of 4.

Results

The qualitative findings led to the identification and confirmation of 22 key indicators categorized into individual, cognitive, and professional characteristics. The quantitative analysis of the decision tree model generated 65 transparent, IF-THEN decision rules. The structural analysis of the tree revealed that the variable "Time Management" acted as the root node, serving as the most critical discriminator in determining the learning paths. Following that, variables such as "Professional Field," "Age," and "Cognitive Approach" appeared at subsequent levels of the hierarchy. Performance evaluation of the proposed model through cross-validation demonstrated exceptional efficiency. The model achieved an average overall accuracy of 0.98 (with a standard deviation of ±0.010), precision of 0.98, recall of 0.96, and an F1-score of 0.97. Class-wise evaluation indicated that the model operated almost flawlessly, with only a marginal 2% misclassification error observed between the

"Workplace Curriculum" and "Public Education" classes due to overlapping skill requirements. Furthermore, to establish statistical superiority, the decision tree model was benchmarked against Logistic Regression, Support Vector Machines (SVM), and Multi-Layer Perceptron (MLP) neural networks. The independent T-test results confirmed that the decision tree significantly outperformed the competing algorithms ($p < 0.05$), providing the best balance between predictive accuracy and interpretability.

Discussion

The transition of higher education from a "one-size-fits-all" traditional approach to intelligent, personalized paradigms requires tools that are not only computationally powerful but also transparent for educational stakeholders. The developed decision tree model successfully addressed this need, proving that heterogeneous individual, cognitive, and academic variables can be mapped into a structured, actionable trajectory. A major finding was the central role of meta-cognitive skills, particularly "Time Management," as the primary filter for advanced specialized paths. This suggests that AI-driven personalization in education is most effective when learners possess a baseline of self-regulation. The extraction of transparent rules circumvents the "black-box" dilemma often associated with artificial intelligence, fostering trust among students and academic advisors. Conclusively, this decision-support tool can drastically reduce educational resource wastage and enhance learning satisfaction. It is highly recommended to integrate this rule-based model as an active module within university Learning Management Systems (LMS) to facilitate dynamic, data-driven academic and career counseling. Future research should focus on expanding the dataset and testing hybrid algorithms to further enhance model stability.

Ethical Considerations

All authors reviewed and approved the final version of the manuscript. The research involved doctoral students who voluntarily participated by completing the questionnaires. The data were collected and analyzed for research purposes.

Acknowledgments

This article is derived from the first author's doctoral dissertation in Curriculum Planning, approved and conducted at Tarbiat Modares University. The authors gratefully acknowledge the moral support of the Research Vice-Presidency of Tarbiat Modares University, the experts who participated in the fuzzy Delphi panel, and all doctoral students who contributed to this study by dedicating their time and carefully completing the questionnaires, thereby making this data-driven research and modeling possible.

Conflict of Interest

The authors declare no financial, professional, or intellectual property conflicts of interest, whether direct or indirect.

AI Disclosure Statement

The authors declare that no artificial intelligence tools were used in the research, data analysis, or preparation of this manuscript.

مطالعات برنامه درسی

شاپا: ۱۷۳۵-۴۹۸۶

https://www.jcsicsa.ir

دوره بیستم، شماره ۷۷، تابستان ۱۴۰۴: ۲۵۰-۲۲۷

طراحی و اعتبارسنجی مدل هوشمند برای شخصی‌سازی مسیرهای یادگیری تخصصی در رشته برنامه‌ریزی درسی مبتنی بر الگوریتم درخت تصمیم

نجما اصغری[۱]، جواد حاتمی*[۲]، فرهاد سراجی[۳]، اسماعیل عظیمی یانچشمه[۴]

۱. دانشجوی دوره دکتری رشته برنامه‌ریزی درسی، دانشکده علوم انسانی، گروه علوم تربیتی، دانشگاه تربیت مدرس، asghari.najma13886@gmail.com، https://orcid.org/0009-0003-0601-8199

۲. *(نویسنده مسئول)* استاد تمام، دانشکده علوم انسانی، گروه علوم تربیتی، دانشگاه تربیت مدرس، j.hatami@modares.ac.ir، http://orcid.org /0000-0002-4517-2039

۳. فرهاد سراجی، استاد تمام، دانشکده روانشناسی و علوم تربیتی، گروه روش‌ها و برنامه‌های درسی و آموزشی ، دانشگاه تهران، fseraji@ut.ac.ir، http://orcid.org /0000-0003-1749-5919

۴. اسماعیل عظیمی یانچشمه، استادیار، دانشکده علوم انسانی، گروه علوم تربیتی، دانشگاه تربیت مدرس، e.azimi@modares.ac.ir، Scopus Author ID: 57095821900

اطلاعات مقاله

نوع مقاله:

مقاله اصیل پژوهشی

کلیدواژه‌ها: شخصی‌سازی یادگیری، رشته برنامه‌ریزی درسی، هوش مصنوعی، الگوریتم درخت تصمیم، مسیرهای یادگیری تخصصی

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۵/۰۳/۱۲

تاریخ بازنگری: ۱۴۰۵/۰۵/۲۸

تاریخ پذیرش: ۱۴۰۵/۰۶/۰۷

چکیده

با توجه به تنوع زیرحوزه‌های رشته برنامه‌ریزی درسی، شخصی‌سازی مسیرهای یادگیری ضرورتی انکارناپذیر است. مقاله حاضر با هدف طراحی و اعتبارسنجی مدلی هوشمند مبتنی بر الگوریتم درخت تصمیم برای نظام‌مندسازی مسیرهای تخصصی یادگیری انجام شد. در این پژوهش کاربردی-ترکیبی، ابتدا شاخص‌ها با مشارکت هشت خبره و روش دلفی فازی شناسایی گردید. سپس داده‌های چهل‌وپنج دانشجوی دکتری از طریق نمونه‌گیری تصادفی طبقه‌ای با ابزار پرسشنامه گردآوری و مدل درخت تصمیم با اعتبارسنجی متقابل آموزش داده شد. بیست‌ودو شاخص در حوزه‌های فردی، شناختی و حرفه‌ای تأیید گردید. مدل شصت‌وپنج قاعده تصمیم استخراج کرد که متغیر مدیریت زمان گره ریشه آن بود. ارزیابی‌ها نشان‌دهنده میانگین دقت کل نودوهشت صدم و برتری آماری معنادار نسبت به روش‌های رقیب بود. این مدل تفسیرپذیر، ابزاری کارآمد برای هدایت تحصیلی و شغلی است. پیشنهاد می‌شود الگوریتم حاضر در سامانه‌های مدیریت یادگیری دانشگاهی ادغام گردد. محدودیت اصلی پژوهش، حجم نمونه کوچک به دلیل محدودیت جامعه آماری دانشجویان دکتری بود.

استناد به این مقاله: اصغری، نجما؛ حاتمی، جواد؛ سراجی، فرهاد؛ عظیمی‌یانچشمه، اسماعیل. (۱۴۰۵). طراحی و اعتبارسنجی مدل هوشمند برای شخصی‌سازی مسیرهای یادگیری تخصصی در رشته برنامه‌ریزی درسی مبتنی بر الگوریتم درخت تصمیم، فصلنامه **مطالعات برنامه درسی ایران**. ۲۱ (۸۱)، ۲۵۰ – ۲۲۷؛ https://doi.org/ 10.22034/jcs.2026.584738.2599

© **نویسندگان**

ناشر: **انجمن مطالعات برنامه درسی ایران.**

مقدمه

توسعه پایدار و متوازن جوامع در گرو پرورش نیروی انسانی متخصص، خلاق و برخوردار از شایستگی‌های حرفه‌ای است؛ نیرویی که بتواند در تحقق اهداف آموزشی و اجتماعی مشارکت مؤثر ایفا کند(Hatami, 2021). در این راستا، نظام‌های آموزشی و به‌ویژه آموزش عالی، مسئولیتی اساسی در تربیت و توانمندسازی چنین سرمایه انسانی‌ای بر عهده دارند. در این میان، رشته برنامه‌ریزی درسی به‌عنوان یکی از رشته‌های دانشگاهی بنیادین در علوم تربیتی، حوزه‌ای پویا، چندبعدی و در حال تحول است که طیف گسترده‌ای از موضوعات (از سیاست‌گذاری تا نسبت میان فناوری و برنامه‌ریزی در سطوح مختلف) را در بر می‌گیرد(Karami, Hejazi, & Tabatabaei, 2016). تلفیق رویکردهایی از حوزه‌هایی نظیر جامعه‌شناسی، فلسفه و روان‌شناسی، به شکل‌گیری روش‌های کاری خاص در این حوزه انجامیده و آن را به حیطه‌ای تخصصی با دامنه کاربردی رو به گسترش در آموزش‌وپرورش عمومی، آموزش عالی و محیط کار تبدیل کرده است(Yadgarzadeh, 2018; Yadgarzadeh et al., 2013; Fathi Vajargah, 2021).

با فراهم شدن پیش‌فرض‌هایی همچون نیاز بازار کار و ساختارهای سازمانی، زمینه برای تخصصی‌شدن زیرحوزه‌های برنامه‌ریزی درسی فراهم شده است. این فرایند به شکل‌گیری و تثبیت مشاغل تخصصی متعددی همچون طراح، مشاور و ارزشیاب برنامه درسی انجامیده و این رشته را از حوزه‌ای صرفاً دانشگاهی به حیطه‌ای کاملاً حرفه‌ای تبدیل کرده است(Yadgarzadeh, 2017). بر این اساس، فعالان این حوزه افزون بر تسلط بر دانش نظری، نیازمند فرصت‌های یادگیری تخصصی برای شکل‌دهی به شخصیت حرفه‌ای خود هستند تا بتوانند خدماتی اثربخش ارائه دهند(Fathi Vajargah, 2022). با این حال، شواهد نشان می‌دهد که بخش قابل‌توجهی از دانش‌آموختگان تحصیلات تکمیلی این رشته، فاقد مهارت‌های پایه و بین‌شغلی مورد نیاز هستند و آموزش‌های دانشگاهی غالبا به مباحث نظری محدود می‌شود. یافته‌های پژوهش Yadgarzadeh (2017)نشان می‌دهد که سرفصل‌های دروس فاقد ویژگی‌های لازم برای تربیت نیروی ماهر است. در نتیجه، برای افرادی که تمایل به فعالیت در یکی از زیرحوزه‌های تخصصی دارند، مسیرهای یادگیری مشخص و هدفمندی تعریف نشده است و برنامه‌های موجود نتوانسته‌اند پیوندی مطلوب میان دانش نظری و نیازهای واقعی میدان عمل برقرار کنند(Mehrmohammadi, 2013; Shahtalebi et al., 2016; Yadgarzadeh, 2017; Fathi Vajargah, 2018).

در چنین بستری، ضرورت بهره‌گیری از سازوکارهای داده‌محور برای ایجاد پیوندی معنادار میان نظر و عمل بیش از پیش آشکار می‌شود. پیشرفت شتابان فناوری‌های آموزشی و ظهور الگوریتم‌های یادگیری ماشین، امکان طراحی این سازوکارها را فراهم ساخته است (Nguyen & Nguyen, 2023; Shemshack & Spector, 2020; Naderi et al., 2026). امروزه بسیاری از سازمان‌های پیشرو، پلتفرم‌های دیجیتال را به‌عنوان هسته مرکزی نظام یادگیری به کار گرفته‌اند. در این پلتفرم‌ها، با بهره‌گیری از الگوریتم‌های هوشمند، مسیرهای یادگیری شخصی‌سازی‌شده‌ای متناسب با نیازها، سطح توانمندی‌ها و علایق فردی طراحی می‌شود و فرایند یادگیری به‌صورت مستمر پایش می‌گردد (FathiVajargah, 2025). با این وجود، باید توجه داشت که در این پژوهش، منظور از مفهوم «شخصی‌سازی مسیر یادگیری تخصصی»، سفارشی‌سازی در سطح سرعت یا توالی محتوای خردِ آموزشی نیست؛ بلکه این مفهوم به‌طور عملیاتی به معنای هدایت تحصیلی–شغلی کلان و پیشنهاد هدفمندِ یکی از سه مسیر

تخصصی (آموزش و پرورش عمومی، آموزش عالی، و برنامه درسی محیط کار) و زیرتخصص‌های حرفه‌ای مرتبط با آن‌ها، بر اساس ترکیب ویژگی‌های فردی، شناختی و حرفه‌ای فراگیران تعریف شده است.

پیشینه پژوهش

در میان الگوریتم‌های متنوع هوش مصنوعی، «درخت تصمیم» به دلیل تفسیرپذیری بالا، توانایی استخراج الگوهای معنادار و کارایی مطلوب در مسائل طبقه‌بندی، به‌عنوان یکی از ابزارهای مؤثر در توسعه مدل‌های توصیه‌گر مسیرهای یادگیری شناخته می‌شود (Jiang, 2021). این الگوریتم با تکیه بر ساختار سلسله‌مراتبی خود، داده‌های یادگیرندگان را بر اساس ویژگی‌هایی همچون اهداف حرفه‌ای، نگرش‌ها و ترجیحات فردی سازمان‌دهی کرده و از طریق تولید قواعد تصمیم‌گیری شفاف، امکان پیشنهاد مسیرهای متناسب را فراهم می‌سازد (Ryoo & Winkelmann, 2021). شفافیت فرایند تصمیم‌سازی و امکان استخراج دانش کاربردی، از مهم‌ترین مزایای این الگوریتم است (Jiang, 2021; Sun, 2024). یافته‌های پژوهشی متعددی نقش مؤثر درخت تصمیم را در هدایت تحصیلی و پیش‌بینی موفقیت تأیید کرده‌اند؛ از جمله Matzavela & Alepis (2021) ، Delahoz-Domínguez & Hijón-Neira (2024) و Barnes et al. (2024) در سطح جهانی، و پژوهش‌های Haghi (2023) ، Ekramifar (2023) و Fathi et al. (2024) در ایران که کارآمدی این الگوریتم را در بهبود مهارت‌ها و ارتقای عملکرد تحصیلی نشان داده‌اند.

با وجود این شواهد موفق، بررسی دقیق پیشینه نشان می‌دهد که یک خلا مطالعاتی اساسی در زمینه بهره‌گیری از هوش مصنوعی برای شخصی‌سازی مسیرهای تخصصی در رشته برنامه‌ریزی درسی وجود دارد (Ojaghi et al., 2023). علی‌رغم طرح مباحث حرفه‌ای این رشته از منظرهای نظری، سوابق پژوهشی نظام‌مند و تجربی در این باره بسیار اندک است (Yadgarzadeh, 2018). وجود طبقه‌بندی‌های تخصصی متنوع (آموزش‌وپرورش عمومی، آموزش عالی و محیط کار) که هر یک نیازمند مهارت‌های متمایزی هستند، ضرورت استفاده از چارچوب‌های داده‌محور را دوچندان می‌کند (Yadgarzadeh et al., 2013; Fathi Vajargah, 2021). فقدان چنین چارچوب‌هایی به سردرگمی دانشجویان، اتخاذ الگوهای آموزشی یکسان، کاهش انگیزش و انتخاب نادرست مسیر علمی منجر شده است (Shahtalebi et al., 2016; Das et al., 2023). نبود یک مدل بومی، هوشمند و تفسیرپذیر که بتواند بر پایه داده‌های واقعی (مانند سوابق تحصیلی و نیازهای بازار کار) مسیرهای یادگیری را پیشنهاد دهد، موجب شده است هدایت تحصیلی عمدتا بر اساس رویکردهای کلی انجام شود.

بر اساس مرور پیشینه و با هدف نظام‌مندسازی متغیرهای پژوهش، چارچوب نظری و مدل مفهومی این مطالعه به‌منظور برقراری ارتباط منطقی میان ویژگی‌های چندبعدی یادگیرندگان و مسیرهای تخصصی تدوین گردید. این مدل نشان می‌دهد که چگونه ویژگی‌های فردی، شناختی و حرفه‌ای فراگیران (به‌عنوان ورودی‌های مدل) از طریق پردازش هوشمند الگوریتم درخت تصمیم ارزیابی شده و در نهایت به یکی از مسیرهای تخصصی و زیرشاخه‌های آن (به‌عنوان خروجی) منتج می‌شوند. ساختار این روابط در شکل (۱) ترسیم شده است:



شکل(۱). مدل مفهومی و چارچوب نظری پژوهش برای شخصی‌سازی مسیرهای یادگیری

بر مبنای این چارچوب مفهومی و هدف تعیین‌شده، پژوهش حاضر می‌کوشد با پر کردن این خلأ پژوهشی، از طریق تلفیق الگوریتم درخت تصمیم(به‌عنوان ابزاری شفاف و تبیین‌پذیر) و اقتضائات حرفه‌ای رشته برنامه‌ریزی درسی، مدلی مبتنی بر هوش مصنوعی طراحی و ارزیابی کند. بر مبنای این هدف، سؤال اصلی پژوهش به‌صورت زیر مطرح می‌شود: «چگونه می‌توان با بهره‌گیری از الگوریتم درخت تصمیم، مدلی مبتنی بر هوش مصنوعی طراحی و اعتبارسنجی کرد که امکان شخصی‌سازی مسیرهای تخصصی یادگیری را برای دانشجویان رشته برنامه‌ریزی درسی فراهم سازد؟»

روش تحقیق

پژوهش حاضر از نظر هدف، کاربردی و با رویکرد ترکیبی (کیفی-کمی) انجام شده است و هدف آن طراحی و اعتبارسنجی مدلی مبتنی بر یادگیری ماشین (الگوریتم درخت تصمیم) برای شخصی‌سازی مسیرهای یادگیری در رشته برنامه‌ریزی درسی است. در راستای پاسخگویی دقیق به اهداف پژوهش و رعایت استانداردهای روش‌شناختی، فرایند اجرا در دو بخش مجزا به شرح زیر انجام گرفت:

در بخش کیفی، هدف شناسایی و تأیید شاخص‌های مؤثر بر شخصی‌سازی مسیر یادگیری بود. روش اجرای این بخش مبتنی بر دلفی فازی در دو دور متوالی بود. جامعه خبرگان شامل متخصصان حوزه برنامه‌ریزی درسی و هوش مصنوعی بود که با استفاده از روش نمونه‌گیری هدفمند و در دسترس، ۸ نفر از آنان برای مشارکت در پژوهش انتخاب شدند. معیارهای ورود خبرگان برنامه‌ریزی درسی به پنل دلفی شامل برخورداری از چندین سال سابقه کار تخصصی و تجربه پژوهشی معتبر

در حوزه‌های آموزش عالی، آموزش ابتدایی و برنامه درسی محیط کار بود. همچنین در خصوص متخصصان هوش مصنوعی، معیار انتخاب علاوه بر تخصص فنی، میزان آشنایی با مسائل آموزشی و درک دقیق از اهداف پژوهش لحاظ گردید.

در بخش کمی، جامعه آماری پژوهش شامل دانشجویان دکتری رشته برنامه‌ریزی درسی در دانشگاه‌های دولتی و غیردولتی کشور بود. با توجه به گستردگی جامعه و عدم دسترسی به آمار دقیق کل این افراد در سطح کشور، برای دستیابی به نمونه‌ای نماینده و متوازن، روش نمونه‌گیری تصادفی طبقه‌ای به کار گرفته شد. در این روش، ملاک طبقه‌بندی بر اساس «حوزه فعالیت حرفه‌ای و شغلی» در نظر گرفته شد؛ به‌نحوی‌که تلاش گردید مشارکت‌کنندگان از طبقات مختلفی نظیر معلمان مقاطع ابتدایی و متوسطه، شاغلین در آموزش عالی و افراد فعال در زمینه برنامه درسی محیط کار از شهرها و گروه‌های جغرافیایی مختلف انتخاب شوند تا تنوع مسیرهای تخصصی به‌خوبی پوشش داده شود .حجم نمونه اولیه با استفاده از فرمول کوکران (با فرض واریانس بیشینه برای جوامع نامشخص)، ۲۰۰ نفر برآورد گردید و لینک پرسشنامه الکترونیکی برای این تعداد از افراد جامعه هدف ارسال شد. از این میان، ۴۵ پرسشنامه به‌صورت کاملاً معتبر و بدون نقص تکمیل و دریافت گردید (نرخ بازگشت ۲۲,۵ درصد). با وجود ریزش نمونه اولیه، با توجه به ماهیت تخصصی پژوهش، دشواری دسترسی به متخصصان این حوزه و کفایت داده‌های به‌دست‌آمده برای تنظیم پارامترهای مدل، همین داده‌های معتبرِ استخراج‌شده مبنای آموزش و ارزیابی مدل الگوریتم درخت تصمیم قرار گرفتند. گردآوری داده‌های میدانی در هر دو بخش کیفی و کمی در بازه زمانی پاییز و زمستان ۱۴۰۵ صورت گرفت.

ابزار اصلی گردآوری داده‌ها در بخش کمی، پرسشنامه‌ای ساختاریافته (محقق‌ساخته) بود که با هدف شناسایی عوامل مؤثر بر تعیین مسیر یادگیری شخصی‌سازی‌شده و استخراج ویژگی‌های مورد نیاز مدل یادگیری ماشین طراحی شد. این پرسشنامه شامل ۹ مؤلفه اصلی و ۲۲ شاخص بود که بر اساس مرور نظام‌مند ادبیات، نیازهای تخصصی رشته برنامه‌ریزی درسی، و نظر خبرگان استخراج و تنظیم گردید .ساختار کامل پرسشنامه در جدول (۱) ارائه شده است.

جدول (۱). مولفه‌ها و شاخص‌های پرسشنامه شخصی‌سازی مسیرهای یادگیری تخصصی در رشته برنامه‌ریزی درسی

مولفه اصلی	شاخص‌ها	توضیحات
اطلاعات جمعیت‌شناختی	سن، سابقه تحصیلی، تجربه حرفه‌ای	توصیف زمینه فردی یادگیرنده و ارتباط آن با سبک‌های یادگیری
ترجیحات یادگیری	نوع منابع آموزشی، سبک مطالعه و محیط مطلوب یادگیری	بیانگر گرایش فرد به یادگیری بصری، شنیداری یا تجربی
علایق تخصصی در رشته	حوزه یادگیری (آموزش عمومی، آموزش عالی، محیط کار)، نوع دانش (نظری، فنی، عملی فکورانه)، مهارت‌ها و شایستگی‌ها	تعیین‌کننده‌ی جهت‌گیری حرفه‌ای و انگیزه‌های علمی فرد
اهداف یادگیری	توسعه و ارتقای حرفه‌ای، کسب مهارت جدید	نشان‌دهنده‌ی مقصد نهایی یادگیرنده در انتخاب مسیر تخصصی

مولفه اصلی	شاخص‌ها	توضیحات
چالش‌ها و نیازهای حمایتی	موانع فردی، کمبود منابع، انتظار از نظام آموزشی	شاخصی از موانع بیرونی و درونی مؤثر بر یادگیری مؤثر
نگرش‌ها و رفتارهای یادگیری	سرعت یادگیری، تعهد به یادگیری بلندمدت	مرتبط با خودنظم‌دهی و پایداری در مسیر یادگیری
الگوهای تصمیم‌گیری	معیارهای انتخاب مسیر، سبک ارزیابی گزینه‌ها	منعکس‌کننده‌ی سازوکارهای شناختی در انتخاب مسیر تخصصی
انتظارات از سیستم شخصی‌سازی	انعطاف‌پذیری، بازخورد هوشمند، تطبیق محتوا	شاخصی از تعامل مطلوب با محیط یادگیری هوشمند
تجربه‌های آموزشی پس از کرونا	میزان استفاده از یادگیری آنلاین، رضایت از آموزش مجازی	مرتبط با سازگاری با محیط‌های دیجیتال و یادگیری ترکیبی

این مؤلفه‌ها و شاخص‌ها در مراحل تحلیل فازی و مدل‌سازی یادگیری ماشین استفاده شدند.

برای بررسی روایی محتوایی، پرسشنامه اولیه در اختیار پنلی متشکل از ۸ نفر از متخصصان حوزه‌های برنامه‌ریزی درسی، هوش مصنوعی و یادگیری دیجیتال قرار گرفت. برای تعیین نسبت روایی محتوا(CVR) ، از رویکرد لاوشه(Lawshe, 1975) استفاده شد که از خبرگان خواسته شد ضرورت هر گویه را در سه طیف ارزیابی کنند. با توجه به تعداد ارزیابان (۸ نفر)، حداقل مقدار قابل‌قبول برای این شاخص ۰,۷۵ در نظر گرفته شد و تمامی ۲۲ شاخص نهایی امتیازی بالاتر از این حدنصاب کسب کردند. همچنین شاخص روایی محتوا(CVI) بر اساس رویکرد والتز و باسل(Waltz & Bausell, 1981) و بر مبنای سه معیار «مربوط بودن، واضح بودن و ساده بودن» بررسی گردید. مقدار CVI برای تمامی گویه‌ها بالاتر از ۰,۷۹ گزارش شد که نشان‌دهنده روایی محتوایی بسیار مطلوب ابزار پژوهش است.

پایایی ابزار با استفاده از ضریب آلفای کرونباخ بر روی داده‌های نمونه ارزیابی شد. ضریب پایایی کل پرسشنامه برابر با ۰,۸۹ محاسبه گردید که نشان‌دهنده انسجام درونی بسیار مطلوب ابزار است. افزون بر این، به‌منظور بررسی دقیق‌تر، پایایی هر یک از ۹ مؤلفه پرسشنامه به‌صورت تفکیک‌شده محاسبه شد که مقادیر تمامی آن‌ها بالاتر از آستانه استاندارد (۰,۷۰) قرار داشت.

در مرحله تحلیل داده‌ها، به‌منظور شناسایی و پالایش شاخص‌های کلیدی مؤثر بر یادگیری شخصی‌سازی‌شده، از روش دلفی فازی استفاده گردید. در این مرحله، پاسخ‌های پرسشنامه در اختیار ۸ نفر از خبرگان رشته برنامه‌ریزی درسی و متخصصان هوش مصنوعی قرار گرفت. در دو دور متوالی، میانگین‌های فازی نظرات خبرگان محاسبه و میزان توافق میان آنان تحلیل شد. یعنی برای هر شاخص، پاسخ‌های فازی متخصصان به روش میانگین‌گیری تجمیع شدند. اگر u_i، m_i و l_i اعداد فازی مثلثی پاسخ‌دهنده‌ی i ام باشد، مقدار فازی تجمیع‌شده به صورت زیر محاسبه می‌شود:

$$\hat{A} = \left(\frac{1}{n}\sum_{i=1}^{n} l_i , \frac{1}{n}\sum_{i=1}^{n} m_i , \frac{1}{n}\sum_{i=1}^{n} u_i\right)$$

سپس، برای فازی‌زدایی از روش مرکز ثقل[1] استفاده شد:

$$Defuzzified = \frac{l + m + u}{3}$$

به عنوان نمونه، برای شاخص «به‌کارگیری فناوری‌های نوین آموزشی»، پس از تجمیع نظرات ۸ متخصص عدد فازی زیر حاصل شد:

A = (۱,۰۵,۱,۳ ,۱,۴۵)

مقدار فازی‌زدایی‌شده آن برابر است با:

DF = (۱,۴۵+۱,۳+۱,۰۵) /۳ =۱,۲۷

به‌منظور بررسی میزان اجماع و توافق خبرگان در دور دوم دلفی، از آزمون آماری «ضریب هماهنگی کندال» استفاده شد. مقدار این ضریب در پایان دور دوم به ۰,۸۲ رسید که نشان‌دهنده سطح توافق قوی و معنادار میان اعضای پنل است. پس از فازی‌زدایی، وزن قطعی هر شاخص به‌دست آمد. برای انتخاب شاخص‌های نهایی، بر اساس رویکرد وو و فانگ (Wu & Fang, 2011) در مطالعات دلفی فازی، مقدار آستانه پذیرش ۰,۷ تعیین گردید؛ بدین‌معنا که شاخص‌هایی که وزن قطعی آن‌ها بالاتر از این مقدار بود، به‌عنوان عوامل منتخب پذیرفته شدند و شاخص‌هایی که امتیاز فازی‌زدایی‌شده‌ی آن‌ها کمتر از ۰,۷ بود (مانند شاخص «ارزیابی مستمر مهارت‌ها») از مدل نهایی حذف گردیدند. با اعمال این فیلتر دقیق، در نهایت دقیقاً ۲۲ شاخص منتخب (که در جدول ۱ نیز ساختاریافته‌اند) به‌عنوان عوامل نهایی تأیید شده و وارد مرحله مدل‌سازی یادگیری ماشین شدند.

برای آموزش مدل درخت تصمیم(CART)، تعیین مسیرهای تخصصی به‌عنوان برچسب‌های خروجی (متغیر وابسته) ضروری بود. به این منظور، ابتدا یک «بانک برچسب» مشتمل بر سه مسیر اصلی شامل «آموزش و پرورش عمومی»، «برنامه درسی محیط کار» و «آموزش عالی» (به‌همراه زیرشاخه‌های تخصصی آن‌ها) با استناد به پیشینه پژوهش استخراج گردید. این چارچوب سپس با مشارکت هشت متخصص و مشاور برنامه‌ریزی درسی اعتبارسنجی شد تا روایی آن در طبقه‌بندی مسیرها تضمین گردد. با وجود این ساختارِ استاندارد، به‌منظور شفاف‌سازی متدولوژیک و پیشگیری از پدیده نشت داده فرآیند استخراج متغیرهای مستقل (۲۲ شاخص ورودیِ مدل) کاملاً از مکانیزم تخصیص برچسب‌ها تفکیک شد. بدین شکل که تخصیص برچسبِ نهایی به هر نمونه، نه بر اساس امتیازات پرسشنامه ورودی، بلکه بر مبنای وضعیت واقعی و مسیر شغلی–تحصیلیِ قطعیِ انتخاب‌شده توسط فراگیران در دنیای واقعی (مستخرج از بخش اطلاعات جمعیت‌شناختیِ فرم‌های پژوهش و پیگیری‌های میدانی) انجام گرفت. این رویکرد اطمینان می‌دهد که متغیر هدف به‌طور کاملاً مستقل از ویژگی‌های ورودی استخراج شده و خطر هرگونه هم‌پوشانی یا نشت داده میان داده‌های آموزش و برچسب نهایی برطرف گردیده است.

1. Center of Gravity

در گام بعد، برای طراحی و ارزیابی مدل، داده‌ها پس از پاک‌سازی و نرمال‌سازی آماده شدند. بررسی توزیع کلاس‌ها در نمونه ۴۵ نفری نشان داد که داده‌ها شامل ۱۶ نمونه در مسیر «آموزش و پرورش عمومی»، ۱۸ نمونه در مسیر «برنامه درسی محیط کار» و ۱۱ نمونه در مسیر «آموزش عالی» بود. در ابتدا داده‌ها به‌صورت ۸۰ درصد آموزش و ۲۰ درصد آزمون تقسیم شدند؛ اما به‌منظور ارزیابی نهایی و جامع‌ترِ عملکرد مدل و جلوگیری از بیش‌برازش، از روش اعتبارسنجی متقابل ۵ بخشی[1] بر روی کل مجموعه داده‌ها استفاده گردید. پارامترهای مدل پس از تنظیم نهایی[2] با این مقادیر در مدل اعمال شدند: معیار تقسیم=Gini، حداکثر عمق درخت = ۵، حداقل نمونه برای تقسیم یک گره = ۴، و حداقل نمونه در برگ = ۲.

برای ارزیابی عملکرد و کارایی مدل، از شاخص‌های استاندارد دقت، صحت، یادآوری و امتیاز F1 استفاده شد. همچنین به‌منظور اعتبارسنجی بیرونی مدل، عملکرد آن با سه الگوریتم رقیب (رگرسیون لجستیک، ماشین بردار پشتیبان و شبکه عصبی) مقایسه گردید. در نهایت سازگاری خروجی‌های مدل با داده‌های واقعی ارزیابی شد تا از کارآمدی مدل در پیشنهاد مسیرهای تخصصی اطمینان حاصل شود.

یافته‌های پژوهش

برای اطمینان از اعتبار ابزار گردآوری داده‌ها، پرسشنامه شخصی‌سازی یادگیری تخصصی، در اختیار هشت نفر از متخصصان رشته برنامه‌ریزی درسی قرار گرفت. نتایج تحلیل پایایی نشان داد که ضریب آلفای کرونباخ کل پرسشنامه برابر با ۰٫۸۹ است که نشان‌دهنده‌ی انسجام درونی مطلوب ابزار می‌باشد. همچنین مقادیر پایایی در ابعاد نه‌گانه پرسشنامه به‌صورت تفکیک‌شده محاسبه گردید که شامل اطلاعات جمعیت‌شناختی (۰٫۷۸)، ترجیحات و سبک یادگیری (۰٫۸۷)، علاقه‌مندی‌ها و حوزه‌های تخصصی (۰٫۸۸)، چالش‌ها و نیازهای حمایتی (۰٫۸۵)، اهداف یادگیری (۰٫۸۲)، نگرش‌ها و رفتارهای یادگیری (۰٫۸۱)، الگوهای تصمیم‌گیری (۰٫۷۹)، انتظارات از سیستم‌های شخصی‌سازی (۰٫۸۴) و تجربه‌های آموزشی پس از کرونا (۰٫۷۸) بود. از آنجا که تمامی این مقادیر بالاتر از آستانه استاندارد ۰٫۷۰ قرار داشتند، ثبات و قابلیت اعتماد مناسب تمامی ابعاد پرسشنامه تأیید شد. افزون بر این، ارزیابی شاخص نسبت روایی محتوا (CVR) بر اساس قضاوت خبرگان، مقادیری بین ۰٫۹۹ تا ۱ را نشان داد که حاکی از روایی محتوای بسیار مطلوب ابزار است. بر این اساس، پرسشنامه از نظر روایی و پایایی، شرایط علمی لازم برای استفاده در پژوهش را دارا بود.

به منظور استخراج شاخص‌ها و معیارهای کلیدی پرسشنامه، دو دور نظرسنجی بر اساس روش دلفی فازی با مشارکت گروهی از متخصصان خبره انجام شد. در دور نخست، ۲۸ شاخص اولیه ارزیابی شد. نتایج دور دوم، که همراه با بازخورد نتایج مرحله قبل انجام شد، نشان‌دهنده افزایش همگرایی نظرات خبرگان بود. در پایان این فرایند، ۲۲ شاخص که مقدار فازی‌زدایی‌شده آن‌ها بالاتر از آستانه تعیین‌شده(θ=۰٫۷) بود، شناسایی و حفظ شدند. این شاخص‌ها پس از ادغام مفهومی، بازنگری محتوایی و تبدیل به گویه‌های قابل سنجش، در قالب ۹ مولفه اصلی و ۲۲ شاخص نهایی در پرسشنامه پژوهش سازمان‌دهی شد. این یافته‌ها نشان می‌دهد که ساختار نهایی پرسشنامه مبتنی بر اجماع خبرگان و پالایش نظام‌مند شاخص‌ها شکل گرفته است.

1. 5-fold Cross-Validation
2. Tuning

برای تحلیل کمی داده‌ها در این پژوهش، از توابع عضویت فازی مثلثی و متقارن[1] استفاده شد. با توجه به استفاده از مقیاس لیکرت ۷ درجه‌ای، دامنه اعداد با گام‌های مساوی ۰,۲۵ تا سقف ۱,۷۵ بسط داده شد تا حساسیت مدل و فواصل محاسباتی حفظ گردد. بر این اساس، گزینه‌های پاسخ پرسشنامه به این شکل به اعداد فازی مثلثی (l, m, u) نگاشت شدند: گزینه «بسیار کم‌اهمیت» معادل (۰,۲۵، ۰,۰۰، ۰,۰۰)، «کم‌اهمیت» معادل (۰,۵۰، ۰,۲۵، ۰,۰۰)، «تا حدی کم‌اهمیت» معادل (۰,۷۵، ۰,۵۰، ۰,۰۰)، «متوسط» معادل (۱,۰۰، ۰,۷۵، ۰,۵۰)، «نسبتاً پراهمیت» معادل (۱,۲۵، ۱,۰۰، ۰,۷۵)، «پراهمیت» معادل (۱,۵۰، ۱,۲۵، ۱,۰۰) و گزینه «بسیار پراهمیت» معادل (۱,۷۵، ۱,۵۰، ۱,۲۵) در نظر گرفته شد. به‌عنوان مثال، اگر یک متخصص در دور دوم نظرسنجی، میزان اهمیت شاخص «انعطاف‌پذیری در مسیر یادگیری» را با امتیاز ۶ (گزینه پراهمیت) مشخص کند، مقدار فازی آن برابر با (۱,۰۰، ۱,۲۵، ۱,۵۰) در نظر گرفته می‌شود.

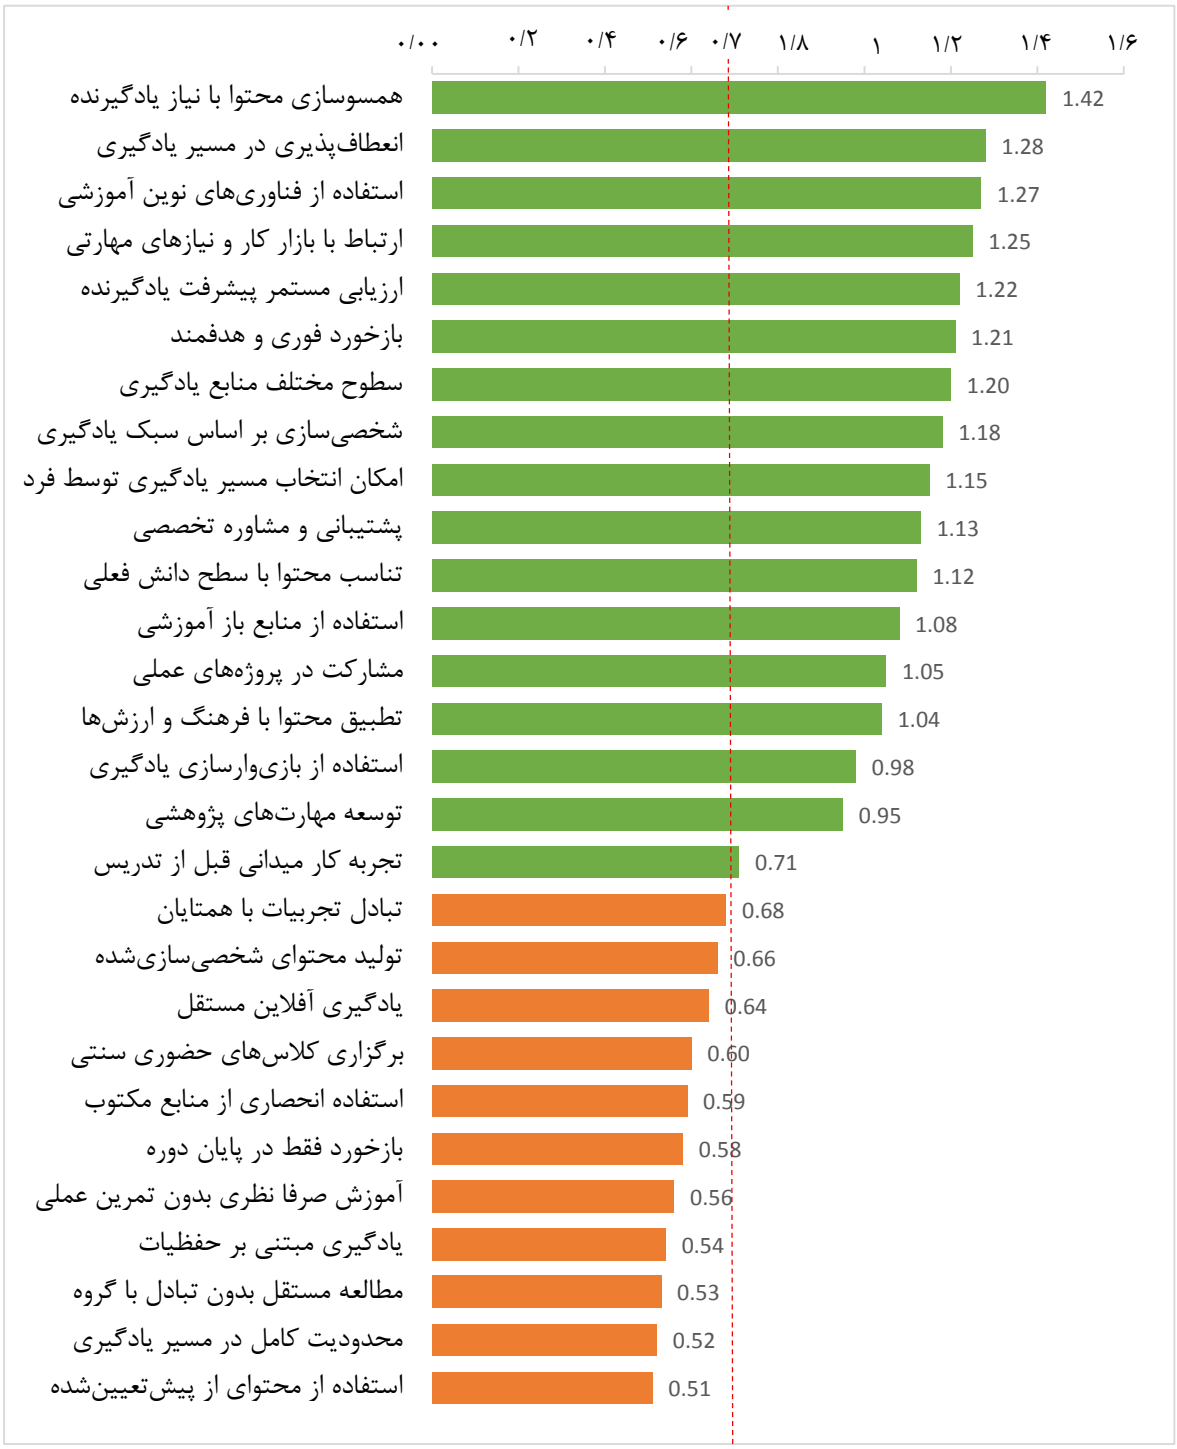
در مرحله بعد، برای هر شاخص، پاسخ‌های فازی متخصصان به روش میانگین‌گیری تجمیع و درجه اهمیت هر شاخص محاسبه گردید. نمونه نتایج این مرحله در جدول (۲) نمایش داده شده است.

جدول (۲). نمونه تجمیع پاسخ‌های فازی متخصصان

ردیف	شاخص	مقدار فازی *(l,m,u)*	*DF*	تصمیم
۱	همسوسازی محتوا با نیاز یادگیرنده	(۱,۵۰, ۱,۴۵, ۱,۳۰)	۱,۴۲	انتخاب شد
۲	انعطاف‌پذیری در مسیر یادگیری	(۱,۴۵, ۱,۳۰, ۱,۱۰)	۱,۲۸	انتخاب شد
۳	تجربه کار میدانی قبل از تدریس	(۰,۷۵, ۰,۷۵, ۰,۶۵)	۰,۷۱	انتخاب شد
۴	ارزیابی مستمر مهارت‌ها	(۰,۶۵, ۰,۵۵, ۰,۴۵)	۰,۵۵	حذف شد

همان‌طور که مشاهده می‌شود، شاخص‌هایی که مقدار فازی و درجه اهمیت (DF) آن‌ها بالاتر از حد تعیین‌شده (آستانه ۰,۷) بود، انتخاب شده و سایر شاخص‌ها حذف شدند. لازم به ذکر است که شاخص‌هایی نظیر «ارزیابی مستمر مهارت‌ها» پس از ارزیابی در دور دوم دلفی، به دلیل پراکندگی بالای نظرات و عدم کسب حدنصاب لازم(DF=۰,۵۵) ، از مجموعه نهایی کنار گذاشته شدند. حذف این‌گونه شاخص‌های دارای عدم توافق، نقش مؤثری در افزایش ضریب هماهنگی و دستیابی به اجماع نهایی و معنادار خبرگان بر روی ۲۲ شاخص منتخب داشت. خروجی این مرحله مبنای انتخاب ویژگی‌های ورودی مدل یادگیری ماشین قرار گرفت. به‌منظور افزایش خوانایی، درک بصری بهتر و مقایسه دقیق‌تر، وزن نهایی تمام شاخص‌ها بر حسب درجه اهمیت در قالب یک نمودار میله‌ای افقی با ترتیب نزولی در نمودار (۱) نمایش داده شده است. همان‌گونه که در این نمودار مشخص است، خط‌چین قرمز رنگ نشان‌دهنده آستانه پذیرش (۰,۷) می‌باشد؛ شاخص‌هایی که وزن نهایی آن‌ها فراتر از این آستانه قرار گرفته است (نوارهای سبز رنگ)، به‌عنوان مؤثرترین عوامل در شخصی‌سازی مسیرهای یادگیری شناسایی و تأیید شدند و شاخص‌های پایین‌تر از آن (نوارهای قرمز رنگ) از مدل حذف گردیدند.

1. Symmetric Triangular Membership Functions



نمودار (۱). توزیع وزن نهایی شاخص‌های ارزیابی‌شده نسبت به آستانه پذیرش

بر اساس نتایج مندرج در نمودار (۱)، شاخص‌هایی که وزن نهایی آن‌ها از آستانه ۰,۷ فراتر رفته است، به‌عنوان مؤثرترین عوامل در شخصی‌سازی مسیرهای یادگیری تأیید شدند. در این میان، عواملی نظیر «همسوسازی محتوا با نیاز یادگیرنده»، «انعطاف‌پذیری در مسیر یادگیری»، «استفاده از فناوری‌های نوین آموزشی» و «ارتباط با بازار کار و نیازهای مهارتی» بالاترین درجه اهمیت را از دیدگاه خبرگان به خود اختصاص دادند. این مجموعه شاخص‌های تأییدشده که از فیلتر تحلیل

فازی عبور کرده‌اند(شامل ۲۲ شاخص)، به‌عنوان ویژگی‌های نهایی و متغیرهای ورودی برای آموزش و طراحی مدل درخت تصمیم انتخاب شدند.

پس از انتخاب شاخص‌های کلیدی، داده‌ها برای ورود به مدل پیش‌پردازش شدند. برای آموزش مدل، داده‌ها به‌صورت تصادفی و با حفظ نسبت کلاس‌ها، به دو بخش آموزش و آزمون تقسیم شدند. الگوریتم درخت تصمیم مبتنی بر روش CART و معیار جینی اجرا شد. در مرحله آموزش، گره‌های تصمیم‌گیری بر اساس ترکیب ویژگی‌های فردی، شناختی و حرفه‌ای ایجاد و مجموعه‌ای از قواعد if-then استخراج شد که منطق تصمیم‌گیری مدل را نشان می‌دهند.

تحلیل ساختار درخت نشان داد که متغیر «مدیریت زمان» نخستین معیار تفکیک‌کننده در رأس درخت است و بیشترین نقش را در تعیین مسیرهای یادگیری دارد. پس از آن متغیرهای «حوزه تخصصی»، «سن»، و «رویکرد شناختی» در سطوح بعدی درخت ظاهر شدند. الگوهای استخراج شده بیان می‌کنند که یادگیرندگانی با مدیریت زمان کمتر، عمدتا به مسیرهای مرتبط با سیاست‌گذاری آموزشی و نقش‌های مدیریتی هدایت شده‌اند، در حالی‌که یادگیرندگانی دارای مدیریت زمان مطلوب و رویکرد شناختی قوی‌تر، در مسیرهای مرتبط با اصلاح و بهبود نظام آموزشی قرار گرفته‌اند. همچنین افراد با رویکرد شناختی ضعیف‌تر ولی نگرشی خلاق، به مسیرهای نوآوری در برنامه‌درسی و بازطراحی محتوا طبقه‌بندی شده‌اند. متغیر سن نیز عامل متمایزکننده مهمی بوده است؛ به‌طوری‌که یادگیرندگان جوان‌تر بیشتر در مسیرهای رهبری آموزشی و سیاست‌گذاری، و یادگیرندگان با سن بالاتر در مسیرهای آموزش تطبیقی و بین‌المللی قرار گرفته‌اند.

نمونه‌هایی از قواعد حاصل‌شده بیانگر عملکرد شفاف و قابل‌تفسیر مدل هستند. پیش از ورود داده‌ها به الگوریتم درخت تصمیم، متغیرهای پژوهش که عمدتاً ماهیتی کیفی یا ترتیبی (طیف لیکرت) داشتند، با استفاده از تکنیک مقیاس‌بندی کمینه–بیشینه[1] در بازه [۰, ۱] نرمال‌سازی شدند. به همین دلیل، در شروط استخراج‌شده از گره‌های درخت، متغیرهایی نظیر «مدیریت زمان» یا «رویکرد شناختی» با مقادیر کمی (مانند ۰,۵) مقایسه می‌شوند. الگوریتم CART با استفاده از معیار جینی، این مقادیر آستانه را به‌عنوان نقطه برش بهینه برای بیشینه‌سازی خلوص گره‌ها انتخاب کرده است؛ به‌طوری‌که مقدار ۰,۵ عملاً نقش مرز تفکیک‌کننده‌ی شدت یک ویژگی (پایین در برابر بالا) را ایفا می‌کند.

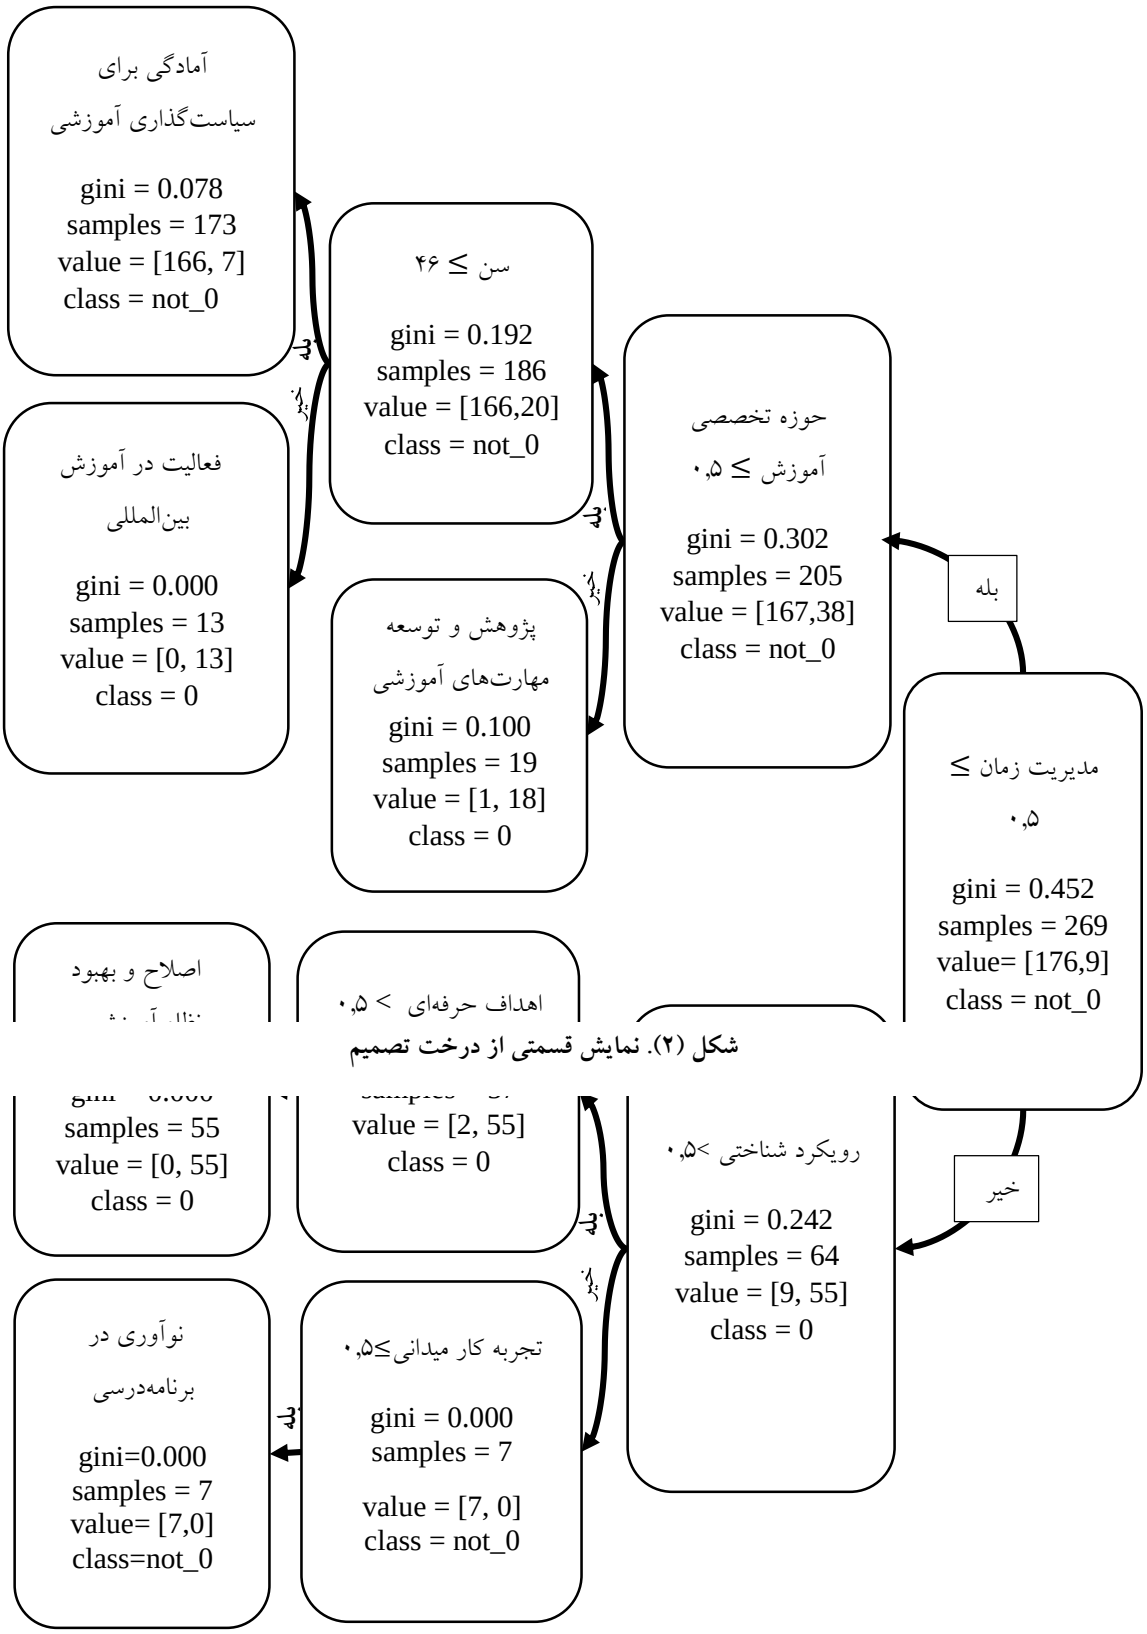
این قواعد مشخص می‌کنند که چگونه ترکیب ویژگی‌های فردی(مانند سن)، شناختی(رویکرد یادگیری)، و حرفه‌ای(مانند مدیریت زمان و حوزه تخصصی) می‌تواند به مسیرهای متفاوت منجر شود. به منظور نشان دادن تنوع قواعد در زیرشاخه‌های مختلف، ۱۰ نمونه از این قوانین در جدول (۳) ارائه شده است (شکاف‌های عددی مربوط به متغیرهای پیوسته نظیر سن نیز بر اساس نقاط برش دقیقِ الگوریتم، پیوسته‌سازی شده‌اند).

1. Min-Max Scaler

جدول (۳). نمونه‌هایی از قوانین تولید شده توسط درخت تصمیم

ردیف	شرط (قاعده استخراج‌شده از گره‌ها)	نتیجه
۱	اگر مدیریت زمان ≥ ۰,۵ و حوزه تخصصی آموزش ≥ ۰,۵ و سن ≥ ۴۶	مسیر یادگیری = آمادگی برای نقش‌های سیاست‌گذاری آموزشی و مدیریتی
۲	اگر مدیریت زمان ≥ ۰,۵ و حوزه تخصصی آموزش ≥ ۰,۵ و سن < ۴۶	مسیر یادگیری = فعالیت در حوزه آموزش بین‌المللی و تطبیقی
۳	اگر مدیریت زمان ≥ ۰,۵ و حوزه تخصصی آموزش < ۰,۵	مسیر یادگیری = پژوهش و توسعه مهارت‌های آموزشی و کاربردی
۴	اگر مدیریت زمان ≥ ۰,۵و رویکرد شناختی < ۰,۵ و اهداف حرفه‌ای < ۰,۵	مسیر یادگیری = اصلاح و بهبود نظام آموزشی موجود
۵	اگر مدیریت زمان < ۰,۵و تجربه کار میدانی ≥ ۰,۵ و سن ≥ ۴۰	مسیر یادگیری = نوآوری در برنامه‌درسی و بازطراحی محتوا
۶	اگر مدیریت زمان < ۰,۵ و استفاده از فناوری‌های نوین ≥ ۰,۵و سن ≥ ۴۰	مسیر یادگیری = طراحی پلتفرم‌های یادگیری دیجیتال و فناوری آموزشی
۷	اگر مدیریت زمان < ۰,۵ و تجربه کار میدانی < ۰,۵ و حوزه یادگیری = محیط کار	مسیر یادگیری = طراحی برنامه‌های آموزشی سازمانی و توسعه منابع انسانی
۸	اگر مدیریت زمان ≥ ۰,۵ و اهداف حرفه‌ای < ۰,۵ و رویکرد شناختی < ۰,۵	مسیر یادگیری = مشاوره تحصیلی و هدایت مسیر یادگیری
۹	اگر انعطاف‌پذیری در مسیر یادگیری < ۰,۵و سن < ۴۰ و حوزه یادگیری = آموزش عالی	مسیر یادگیری = توسعه برنامه‌های درسی دانشگاهی
۱۰	اگر انعطاف‌پذیری در مسیر یادگیری ≥ ۰,۵ و ارزیابی مستمر پیشرفت < ۰,۵	مسیر یادگیری = سنجش و ارزشیابی آموزشی در مدارس

این مجموعه، نمونه‌ای از ۶۵ مسیر تصمیم استخراج‌شده از درخت است که ماهیت شفاف و قابل‌تعبیر مدل را به‌خوبی نشان می‌دهد. هر قانون با دقت ریاضی توضیح می‌دهد که ترکیب چه ویژگی‌هایی در سطوح مختلف آموزشی(آموزش عمومی، عالی و محیط کار) به انتخاب کدام مسیر یادگیری منجر می‌شود. این مدل با ارائه قوانین قابل‌تعبیر، بدون شکاف و تکرارپذیر، امکان تبیین رفتار یادگیرندگان را فراهم می‌کند و پایه‌ای مستحکم برای طراحی سیستم‌های هوشمند توصیه‌گر آموزشی فراهم می‌آورد. شکل (۲) قسمتی از ساختار درخت تصمیم را نشان می‌دهد.



شکل (۲). نمایش قسمتی از درخت تصمیم

این نمایش گویای آن است که چگونه ترکیب ویژگی‌های فردی، شناختی و حرفه‌ای یادگیرندگان، مسیرهای یادگیری متفاوتی را تعیین می‌کند. در این ساختار گره‌های بالایی نقش تعیین‌کننده‌تری در طبقه‌بندی دارند و مسیرهای مختلف بر اساس شرایط if-then استخراج می‌شوند.

برای ارزیابی دقیق مدل، علاوه بر شاخص‌های کلی عملکرد، نتایج به‌تفکیک هر یک از کلاس‌های هدف (مسیرهای تخصصی سه‌گانه) محاسبه گردید. ارزیابی تفکیک‌شده به شناسایی دقیق نقاط قوت و ضعف مدل در طبقه‌بندی هر مسیر یادگیری کمک می‌کند. نتایج به‌دست‌آمده برای شاخص‌های دقت، دقت مثبت‌نما، یادآوری و امتیاز F1 در جدول (۴) گزارش شده است.

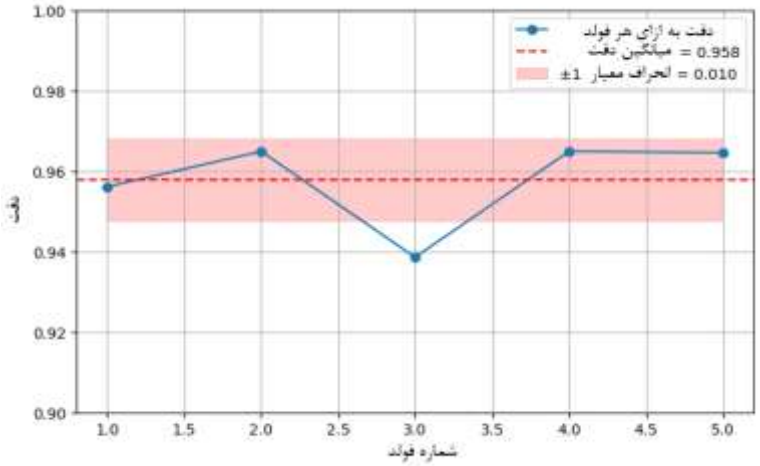
جدول (۴). شاخص‌های عملکرد مدل پیشنهادی

مسیر تخصصی(کلاس)	دقت	دقت مثبت‌نما	یادآوری	امتیاز اف-۱
آموزش و پرورش عمومی	۰,۹۸	۰,۹۸	۰,۹۷	۰,۹۷
برنامه درسی محیط کار	۰,۹۷	۰,۹۷	۰,۹۵	۰,۹۶
برنامه درسی آموزش عالی	۰,۹۹	۰,۹۹	۰,۹۸	۰,۹۸
میانگین کل	۰,۹۸	۰,۹۸	۰,۹۶	۰,۹۷

همان‌طور که مقادیر جدول (۴) نشان می‌دهند، مدل در تشخیص تمامی مسیرها عملکردی متعادل و متمایل به یک دارد و میانگین دقت کلی مدل در اعتبارسنجی نهایی برابر با ۰,۹۸ به‌دست آمد. بررسی ماتریس درهم‌ریختگی نشان داد که از مجموع نمونه‌های ارزیابی‌شده، تنها درصد بسیار ناچیزی از خطای طبقه‌بندی (حدود ۲ درصد) مربوط به هم‌پوشانی و شباهت ویژگی‌ها میان «برنامه درسی محیط کار» و «آموزش و پرورش عمومی» بوده است. در مقابل، مدل در تفکیک کلاس «آموزش عالی» تقریباً بدون هیچ‌گونه خطای منفی کاذب عمل کرده است. افزون بر این، ارزیابی شاخص مساحت زیر منحنی[1] برای کلاس‌های سه‌گانه حاکی از آن است که مدل به ترتیب مقادیر ۰,۹۸، ۰,۹۷ و ۰,۹۹ را کسب نموده است. این شواهد ترکیبی، نشان‌دهنده توانایی و قدرت تفکیک بسیار بالای الگوریتم درخت تصمیم در مرزبندی دقیق الگوهای یادگیری فراگیران است.

همچنین در استفاده از اعتبارسنجی متقابل پنج‌تایی(k=5)، میانگین دقت کلی مدل و انحراف معیار آن به‌صورت نمودار (۲) محاسبه شد.

1. ROC-AUC



نمودار(۲). دقت و انحراف معیار مدل پیشنهادی

همان‌طور که نمودار نشان می‌دهد، میانگین دقت مدل برابر با ۰,۹۵۸ و انحراف معیار ۰,۰۱۰± به‌دست آمد که بیانگر پایداری، ثبات در یادگیری و قابلیت تعمیم مناسب مدل در مواجهه با داده‌های جدید است.

به منظور سنجش میزان کارایی و تایید برتری چارچوب پیشنهادی، عملکرد مدل درخت تصمیم با سه الگوریتم متداول و پرکاربرد «رگرسیون لجستیک»، «ماشین بردار پشتیبان» و «شبکه عصبی» مورد مقایسه قرار گرفت.

بررسی نتایج ارائه‌شده در جدول(۵) نشان می‌دهد که مدل پیشنهادی در تمامی شاخص‌های ارزیابی موفق به کسب رتبه نخست شده است. مقادیر دقت، صحت، یادآوری و امتیاز F1 برای مدل درخت تصمیم نسبت به سایر الگوریتم‌ها افزایش معناداری داشته است. این برتری عملکردی بیانگر آن است که ساختار درخت تصمیم با ماهیت داده‌های این پژوهش و اهداف شخصی‌سازی مسیرهای یادگیری سازگاری بیشتری نسبت به مدل‌های خطی(مانند رگرسیون لجستیک) و مدل‌های پیچیده‌تر(مانند شبکه عصبی) دارد. در نتیجه، مدل پیشنهادی توانسته است با تعادلی بهینه بین دقت و تفسیرپذیری، بهترین پاسخ را برای مسئله مورد مطالعه ارائه دهد.

جدول (۵). مقایسه عملکرد مدل پیشنهادی با سایر روش‌ها

مدل طبقه‌بندی	*دقت*	*دقت مثبت‌نما*	*یادآوری*	*امتیاز اف-۱*
رگرسیون لجستیک	۰,۹۳	۰,۹۲	۰,۹۱	۰,۹۱
ماشین بردار پشتیبان	۰,۹۵	۰,۹۴	۰,۹۳	۰,۹۴
شبکه عصبی چندلایه	۰,۹۶	۰,۹۵	۰,۹۴	۰,۹۵
درخت تصمیم‌گیری	۰,۹۸	۰,۹۸	۰,۹۶	۰,۹۷

علاوه بر نتایج جدول (۵)، بررسی تفاوت عملکرد مدل‌ها از طریق آزمون آماری تی-مستقل[1] بر روی نتایج اعتبارسنجی متقابل نشان داد که برتریِ دقت مدل درخت تصمیم (۰,۹۸) نسبت به بهترین مدل رقیب یعنی شبکه عصبی (۰,۹۶)، از نظر آماری

1. T-test

کاملاً معنادار است ($p < 0.05$). در نهایت، مقایسه الگوهای استخراج‌شده با ادبیات پژوهش تأیید می‌کند که این مدل پیشنهادی نه‌تنها از نظر الگوریتمی و آماری برتری دارد، بلکه از لحاظ محتوایی نیز قادر است مسیرهای یادگیریِ متناسب با ویژگی‌های فردی و نیازهای حرفه‌ای فراگیران را در سه حوزه «آموزش و پرورش عمومی»، «آموزش عالی» و «برنامه درسی محیط کار» به‌درستی استخراج و پیشنهاد دهد.

بحث یافته‌ها

یافته‌های پژوهش نشان داد که مدل طراحی‌شده مبتنی بر الگوریتم درخت تصمیم توانسته است با دستیابی به مقادیر بالای دقت، صحت و امتیاز F1 ، عملکرد مطلوبی در پیش‌بینی و شخصی‌سازی مسیرهای تخصصی یادگیری ارائه دهد. از منظر مفهومی، این نتایج بیانگر آن است که استفاده از مدل‌های داده‌محور و تفسیرپذیر، امکان استخراج الگوهای یادگیری متناسب با تفاوت‌های فردی را فراهم می‌سازد و می‌تواند به‌عنوان ابزاری قابل اتکا در محیط‌های یادگیری مجازی استفاده شود.

در همین راستا، تحلیل یافته‌های حاصل از اعتبارسنجی مدل نشان داد که ساختار طراحی‌شده مبتنی بر الگوریتم درخت تصمیم، از پایداری و قابلیت تعمیم‌پذیری بسیار بالایی برخوردار است. دستیابی به میانگین دقت ۰,۹۵۸ در اعتبارسنجی متقابل پنج‌تایی در کنار نوسان بسیار ناچیز (انحراف معیار ±۰,۰۱۰)، از منظر تحلیلی بیانگر آن است که مدل پیشنهادی به داده‌های اولیه بیش‌برازش[1] نشده و قادر است الگوهای یادگیری را در مواجهه با نمونه‌های جدید نیز به‌درستی تشخیص دهد. توازن مناسب میان شاخص‌های دقت و یادآوری در مرحله ارزیابی، تأیید می‌کند که این سیستم توصیه‌گر از سوگیری الگوریتمی به سمت یک مسیر تخصصی خاص اجتناب کرده است؛ موضوعی که از منظر عدالت آموزشی بسیار حائز اهمیت است و نشان می‌دهد مدل می‌تواند بدون محدودسازی فرصت‌ها، توصیه‌هایی منصفانه و مبتنی بر تفاوت‌های فردی ارائه دهد.

تحلیل عمیق‌تر داده‌ها مشخص کرد که متغیرهایی نظیر مدیریت زمان، حوزه علاقه‌مندی تخصصی، سن، زمینه تحصیلی پیشین و رویکرد شناختی نقش تعیین‌کننده‌ای در انتخاب مسیرها دارند. برجسته شدن «مدیریت زمان» به‌عنوان عامل تفکیک‌کننده اصلی در راس درخت تصمیم(گره ریشه)، حاکی از آن است که توانایی خودتنظیمی، پیش‌شرط اساسی برای ورود به مسیرهای تخصصی پیچیده‌تر است. در مقایسه با پژوهش‌های داخلی نظیر پژوهش حقی و اکرامی‌فر (Haghi, 2023؛ Ekramifar, 2023) که عمدتاً بر تاثیر مستقیم پیشینه و نتایج تحصیلی بر پیشرفت تمرکز داشته‌اند، یافته‌های این مطالعه نشان می‌دهد که ترکیب متغیرهای رفتاری (نظیر مدیریت زمان) با ویژگی‌های شناختی، قدرت تبیین بسیار بالاتری در شخصی‌سازی یادگیری دارد. همچنین، برخلاف مطالعه سان (Sun, 2024) که خودتنظیمی را تنها به‌عنوان یک متغیر مکمل در محیط‌های خطی بررسی کرده بود، ساختار درختی این پژوهش اثبات کرد که در مسیرهای انعطاف‌پذیر، مدیریت زمان نقش فیلتر اولیه را برای هدایت به شاخه‌های تخصصی ایفا می‌کند.

از سوی دیگر، ساختار سلسله‌مراتبی مدل امکان تحلیل روابط پیچیده میان متغیرها را فراهم کرد. قواعد تصمیم استخراج‌شده نشان می‌دهند که نه یک عامل منفرد، بلکه ترکیبی از متغیرها نقش اساسی در تعیین مسیرها دارند. این یافته با نتایج ریو و وینکل‌من (Ryoo & Winkelmann, 2021) هم‌راستا است؛ با این تفاوت که مطالعه آن‌ها بیشتر بر جنبه‌های منفردِ

1. Overfit

شناختی تاکید داشت، اما مدل فعلی نشان داد که ادغام رویکردهای شناختی با اهداف حرفه‌ای (همان‌طور که Barnes et al., 2024نیز به‌صورت نظری اشاره کرده‌اند) به کاهش چشمگیر خطای طبقه‌بندی و افزایش دقت توصیه‌ها منجر می‌شود.

با وجود دستاوردهای مطلوب، تفسیر یافته‌های این پژوهش باید با توجه به محدودیت‌های ذاتی مدل‌های یادگیری ماشین صورت گیرد. از منظر الگوریتمی، درخت تصمیم علی‌رغم شفافیت و تفسیرپذیری بالا، محدودیت‌هایی نظیر حساسیت به تغییرات کوچک در داده‌های آموزشی و عمق محدود دارد. افزون بر این، در صورت استفاده از داده‌هایی با ابعاد بسیار بالا، این الگوریتم مستعد مشکل بیش‌برازش است. اگرچه در این مطالعه با تنظیم پارامترها و هرس کردن درخت[1] تلاش شد تا پایداری مدل حفظ شود، اما برای تعمیم‌پذیری در مقیاس‌های کلان‌تر، ممکن است نیاز به استفاده از مدل‌های ترکیبی مقاوم‌تر احساس شود.

درمجموع، مدل پیشنهادی با اتکا بر رویکردی داده‌محور توانسته است تعاملات پیچیده یادگیرندگان را بازنمایی کند. از نظر پیامدهای عملی، پیاده‌سازی این مدل به‌عنوان یک سیستم توصیه‌گر در سامانه‌های مدیریت یادگیری دانشگاه‌ها با چالش‌های اجرایی همراه خواهد بود. ادغام چنین مدلی نیازمند استانداردسازی پایگاه‌های داده آموزشی، یکپارچه‌سازی زیرساخت‌ها و رعایت دقیق اصول حریم خصوصی در جمع‌آوری داده‌های رفتاری فراگیران است. علاوه بر این، غلبه بر چالش‌های پذیرش فناوری توسط کاربران (اساتید و دانشجویان) امری حیاتی است؛ موفقیت این سیستم منوط به طراحی رابط‌های کاربری تعاملی است که منطق توصیه‌های الگوریتم را برای یادگیرنده شفاف سازد تا اعتماد آن‌ها به مسیرهای شخصی‌سازی‌شده جلب گردد.

نتیجه‌گیری

پژوهش حاضر نشان داد که گذار نظام‌های آموزش عالی از رویکردهای سنتی و «یکپارچه برای همه» به سمت الگوهای هوشمند و شخصی‌سازی‌شده، نیازمند ابزارهایی است که علاوه بر توانایی در تحلیل داده‌های پیچیده، از شفافیت و قابلیت تفسیر برای ذی‌نفعان آموزشی برخوردار باشند. مدل توسعه‌یافته در این مطالعه با بهره‌گیری از الگوریتم درخت تصمیم، این نیاز مبرم را با موفقیت پاسخ داد و ثابت کرد که می‌توان متغیرهای ناهمگنِ فردی، شناختی و تحصیلی را به یک نقشه راه عملی و ساختاریافته تبدیل کرد.

نتایج این مطالعه گویای آن است که شکل‌گیری یک مسیر یادگیری تخصصی موفق، تابعی از تعامل پویای مهارت‌های فراشناختی با اهداف حرفه‌ای است. استقرار مهارت‌هایی نظیر «مدیریت زمان» در کانون این مدل، تأیید می‌کند که فناوری‌های هوشمند تنها زمانی در شخصی‌سازی یادگیری مؤثر می‌افتند که یادگیرنده از حداقل توانمندی‌های خودتنظیمی برخوردار باشد. در نتیجه، این مدل فراتر از یک الگوریتم دسته‌بندی ساده، به‌عنوان یک چارچوب مفهومی عمل می‌کند که انطباق عمیق آموزش‌های دانشگاهی با علایق پژوهشی و نیازهای بازار کار را تسهیل می‌نماید.

مهم‌ترین دستاورد کاربردی این پژوهش، ارائه یک ابزار تصمیم‌یارِ قابل‌اعتماد برای سامانه‌های مدیریت یادگیری (LMS) است. برخلاف مدل‌های «جعبه سیاه» در هوش مصنوعی که منطق تصمیم‌گیری آن‌ها برای کاربر مبهم است، قواعد

1. Pruning

شفافِ مستخرج از این مطالعه می‌تواند اعتماد دانشجویان و اساتید را جلب کرده و فرآیند مشاوره تحصیلی را از حالت شهودی به حالت داده‌محور ارتقا دهد. این الگو نه‌تنها اتلاف منابع آموزشی را کاهش می‌دهد، بلکه رضایت‌مندی و اثربخشی یادگیری را در محیط‌های آموزش رسمی و مجازی به‌طور ملموسی افزایش خواهد داد.

پیشنهادها

با توجه به نتایج و یافته‌های پژوهش حاضر، پیشنهادهای زیر در دو سطح کاربردی و پژوهشی ارائه می‌گردد:

الف) پیشنهادهای کاربردی (برای نظام آموزش عالی و توسعه‌دهندگان)

- اجرای پایلوت در دانشگاه‌ها: با توجه به یافته پژوهش مبنی بر دقت بسیار بالای مدل (۰,۹۸) و متوازن بودن آن در اجتناب از سوگیری(امتیاز F1 معادل ۰,۹۷)، پیشنهاد می‌شود مدل حاضر به‌عنوان هسته مرکزی یک سامانه مشاوره هوشمند تحصیلی–شغلی در دانشکده‌های علوم تربیتی مورد استفاده قرار گیرد. این سامانه می‌تواند در مقاطع تحصیلات تکمیلی، به دانشجویان در انتخاب گرایش و پروژه‌های پژوهشی متناسب با نیمرخ شخصی آن‌ها کمک کند.
- ادغام در سامانه‌های مدیریت یادگیری (LMS): بر اساس یافته پژوهش مبنی بر شفافیت و قابلیت تفسیرپذیری الگوریتم درخت تصمیم (استخراج ۶۵ قاعده شفاف)، می‌توان این قواعد را مستقیماً به ماژول‌هایی در سامانه‌های مدیریت یادگیری تبدیل کرد تا به‌صورت خودکار، منابع تکمیلی یا دوره‌های کوتاه‌مدت را پیشنهاد داده و مسیر یادگیری دانشجو را پویا سازند.
- توسعه بانک اطلاعاتی پویا: نظر به اینکه یافته‌ها نشان داد متغیرهای فردی و زمینه تحصیلی نقش پویایی در تعیین مسیر دارند، ایجاد یک بانک اطلاعاتی ملی از نیمرخ‌های فارغ‌التحصیلان موفق رشته برنامه‌ریزی درسی ضروری است. این کار به مدل اجازه می‌دهد با تغذیه از داده‌های غنی‌تر، توصیه‌های خود را به‌طور مستمر کالیبره و دقیق‌تر کند.

ب) پیشنهادهای پژوهشی (برای مطالعات آتی)

- تعمیم و اعتبارسنجی بین‌رشته‌ای: با توجه به موفقیت چارچوب روش‌شناختی مدل در طبقه‌بندی دقیق مسیرهای تخصصی رشته برنامه‌ریزی درسی، آزمون این ساختار در سایر رشته‌های علوم انسانی یا فنی–مهندسی که نیاز به انتخاب مسیر تخصصی دارند، پیشنهاد می‌شود تا یک چارچوب عام برای شخصی‌سازی مسیر یادگیری تدوین گردد.
- تلفیق با الگوریتم‌های ترکیبی: عنایت به بحث مطرح‌شده پیرامون محدودیت‌های ذاتی درخت تصمیم (نظیر حساسیت به تغییرات داده و خطر بیش‌برازش در ابعاد بالا)، پیشنهاد می‌شود در پژوهش‌های آینده، این الگوریتم با روش‌های مجموعه‌ای مانند جنگل تصادفی[1] یا شبکه‌های عصبی ترکیب شود تا همزمان قدرت تفسیر و پایداری مدل ارتقا یابد.
- در نظرگیری متغیرهای پویا و بافتی: از آنجا که یافته‌ها اثبات کردند متغیرهای رفتاری (مانند مدیریت زمان به‌عنوان گره ریشه درخت) نقش فیلتر اولیه را دارند، مطالعات آینده می‌توانند متغیرهای رفتاریِ پویاتری نظیر تعاملات اجتماعی بلادرنگ[2] در کلاس‌های مجازی یا بازخوردهای آنی اساتید را به مجموعه شاخص‌های مدل اضافه کنند.

1. Random Forest
2. Real-time

- ارزیابی طولیِ اثرات: پیرو یافته مفهومی پژوهش مبنی بر انطباق سیستماتیک مسیرهای آموزشی با اهداف حرفه‌ای، انجام مطالعات طولی‌مدت پیشنهاد می‌شود تا بررسی گردد آیا دانشجویانی که مسیرشان با این مدل شخصی‌سازی شده، در مقایسه با گروه کنترل، از انطباق بهتری با نیازهای بازار کار برخوردارند یا خیر.
- تمرکز بر اخلاق و حریم خصوصی: از آنجا که عملکرد مطلوب این مدل وابستگی مستقیمی به جمع‌آوری و تحلیل داده‌های حساسِ فردی، شناختی و تحصیلی (۲۲ شاخص) داشت، پژوهش‌های آینده باید به طراحی چارچوب‌های اخلاقی حفظ حریم خصوصی و همچنین بررسی ادراک و پذیرش این فناوری از سوی کاربران بپردازند.

مشارکت نویسندگان

مشارکت نویسنده اول شامل ایده‌پردازی، طراحی چارچوب مفهومی، گردآوری داده‌های میدانی، مدل‌سازی مبتنی بر یادگیری ماشین و نگارش پیش‌نویس اصلی مقاله (۵۰٪) بوده است. نویسنده دوم (نویسنده مسئول) مسئولیت نظارت و راهبری علمی پژوهش، اعتبارسنجی متدولوژی و ویرایش تخصصی-محتوایی مقاله را بر عهده داشته است (۲۰٪). همکاری نویسنده سوم در زمینه ارائه مشاوره تخصصی در بخش کیفی (دلفی فازی)، تحلیل یافته‌ها و بازبینی ساختاری مقاله بوده (۱۵٪) و نویسنده چهارم نیز در ارائه مشاوره برای تحلیل‌های کمی، ارزیابی عملکرد الگوریتم درخت تصمیم و بازبینی نهایی مقاله مشارکت داشته است (۱۵٪). کلیه نویسندگان نسخه نهایی مقاله را مطالعه و محتوای آن را تأیید نموده‌اند.

تشکر و قدردانی

مقاله حاضر، مستخرج از رساله دکتری تخصصی رشته برنامه‌ریزی درسیِ نویسنده اول، مصوب و اجرا شده در **دانشگاه تربیت مدرس** می‌باشد. بدین‌وسیله نویسندگان مراتب سپاس و قدردانی ویژه خود را از حمایت‌های معنوی معاونت پژوهشی دانشگاه تربیت مدرس، اساتید و متخصصان خبره در پنل دلفی، و تمامی دانشجویان دکتری که با اختصاص زمان و تکمیل دقیق پرسشنامه‌ها، انجام این پژوهش و مدل‌سازی داده‌محورِ آن را امکان‌پذیر ساختند، ابراز می‌دارند.

تعارض منافع

هیچ‌گونه تعارض منافع (مالی مستقیم، مالی غیرمستقیم، تعارض حرفه‌ای و مالکیت فکری) توسط نویسندگان بیان نشده است.

بیانیه نحوه استفاده از هوش مصنوعی

نویسندگان اعلام می‌دارند که در فرایند انجام پژوهش، تحلیل داده‌ها و نگارش مقاله حاضر، از ابزارهای هوش مصنوعی استفاده نشده است.

References

Barnes, E., Hutson, J., & Perry, K. (2024). Enhancing adult learner success in higher education through decision tree models: A machine learning approach. **Forum for Education Studies**, 2(3), Article 1415. https://doi.org/10.59400/fes.v2i3.1415

Das, A., Malaviya, S., & Singh, M. (2023). The impact of AI-driven personalization on learners' performance. International **Journal of Computer Sciences and Engineering**, 11(8), 15–22. https://doi.org/10.26438/ijcse/v11i8.1522

Delahoz-Domínguez, E. J., & Hijón-Neira, R. (2024). Recommender system for university degree selection: A socioeconomic and standardised test data approach. **Applied Sciences,** 14(18), Article 8311. https://doi.org/10.3390/app14188311

Ekramifar, M. (2023). Predicting student performance using decision tree algorithm [Master's thesis, Ministry of Science and Research]. IranDoc. ://ganj.irandoc.ac.ir/viewer/a501ab5ba6fcb4e80106c5cf6257e442. [In Persian].

Fathi, F., Fathi-Vajargah, K., Jafari, E., & Vahidi-Asl, M. (2024). Designing a workplace digital curriculum based on artificial intelligence components. **Human Information Interaction**, 11(3), 71–92. http://hii.khu.ac.ir/article-1-3183-en.html. [In Persian].

Fathi-Vajargah, K. (2018). Toward the third wave in curriculum studies in Iran: Moving beyond neo-understanding and in search of pluralism in curriculum climates. **Journal of Higher Education Curriculum Studies,** 18(9), 45–69. https://www.noormags.ir/view/en/articlepage/downloadpdf/1436387. [In Persian].

Fathi-Vajargah, K. (2021). Curriculum identities: An account of curriculum theorists' perspectives during classical, neo-understanding, and post-neo-understanding periods (Vol. 1). **Ayezh Publications**. [In Persian].

Fathi-Vajargah, K. (2022). A new dream: Multi-grounding curriculum studies in the new century (From a landless discipline to a borderless discipline). **Iranian Journal of Curriculum Studies,** 17(65), 7–26. https://doi.org/20.1001.1.17354986.1401.17.65.2.0. [In Persian].

Fathi-Vajargah, K. (2025). The implications of technological transformations for the field of curriculum with a neo/multi-platforming approach: From learning experience platforms to guerrilla curriculum. **Journal of Education and Human Resource Development**, 11(42)]. https://doi.org/10.61882/istd.49893.11.42.150. [In Persian].

Haghi, M. (2023). Predicting the performance of medical students based on educational data analysis using data mining techniques (Case study: Some medical universities) [Master's thesis, Iran University of Science and Technology]. https://ganj.irandoc.ac.ir/viewer/be4b29c28ce434c7bd1dad24cbcd74e7. [In Persian].

Hatami, J. (2021). Competency-based curriculum: An undeniable necessity. **Journal of Higher Education Curriculum Studies**, 12(24). https://dor.isc.ac/dor/20.1001.1.25382241.1400.12.24.2.4. [In Persian].

Jiang, X. (2021). Online English teaching course score analysis based on decision tree mining algorithm. **Complexity**, 2021, Article 5577167. https://doi.org/10.1155/2021/5577167

Karami, M., Hejazi, Z., & Tabatabaei, M. S. (2016). Identification, comparison, and analysis of dominant and neglected thematic trends in university textbooks of curriculum studies in Iran and the world. **Research and Writing of University Textbooks,** 20(38), 48–63. https://doi.org/20.1001.1.26767503.1395.20.38.3.7. [In Persian].

Lawshe, C. H. (1975). A quantitative approach to content validity**. Personnel Psychology**, 28(4), 563-575. https://doi.org/10.1111/j.1744-6570.1975.tb01393.x

Matzavela, V., & Alepis, E. (2021). Mobile learning analytics and decision trees for student performance prediction. **Education and Information Technologies**, 26(3), 2983–3002. https://doi.org/10.1007/s10639-020-10341-9

Mehrmohammadi, M. (2013). Clarifying the mutual expectations of the curriculum studies academic community and the educational system: A discussion on reconstructing the professional status of the

field and its graduates in Iran. **Theory and Practice in Curriculum Studies**, 1(2), 47–64. http://cstp.khu.ac.ir/article-1-1917-fa.html. [In Persian].

Naderi, R., Hatami, J., Vedadhir, A.A., Fakhroleslam, M. & Tekyekhah.R.S. (2026). The Futureof Educational Systems and Curriculum Based on Generative Artificial Intelligence: A Systematic Review. **Iranian Journal of curriculum studies.** 21 (80). https://doi.org/ 10.22034/jcs.2026.539210.2476. [In Persian].

Nguyen, H. H., & Nguyen, V. A. (2023). Personalized learning in the online learning from 2011 to 2021: A bibliometric analysis. **International Journal of Information and Education Technology**, 13(8), 1261–1272. https://doi.org/10.18178/ijiet.2023.13.8.1928

Ojaghi, H., Zohourian-Nadali, I., & Soleimani-Rozbehani, F. (2023). Mapping the ecosystem of artificial intelligence products and producers in Iran based on transformative scope. **Iranian Journal of Information and Communication Technology**, 57(57), 138–152. https://rimag.ricest.ac.ir/Article/44108/jour.aicti.ir. [In Persian].

Ryoo, J., & Winkelmann, K. (Eds.). (2021). Innovative learning environments in STEM higher education: Opportunities, challenges, and looking forward. **Springer**. https://doi.org/10.1007/978-3-030-58948-6

Shah Talebi, S., Liaghatdar, M. J., & Sharifian, F. (2016). Skill competencies of doctoral graduates in curriculum studies in Iran: Review of experts' and specialists' perspectives. **Journal of Curriculum Planning Research,** 13(51), 21–37. [In Persian].

Shemshack, A., & Spector, J. M. (2020). A systematic literature review of personalized learning terms. **Smart Learning Environments,** 7(1), Article 1. https://doi.org/10.1186/s40561-020-00140-9.

Sun, Y. (2024). Decision trees for evaluating blended learning effectiveness in higher education. **Journal of Educational Technology Systems**, 53(2), 112–134. https://doi.org/10.1177/00472395241234456

Waltz, C. F., & Bausell, R. B. (1981). Nursing research: Design, statistics, and computer analysis. **F. A. Davis Company.**

Wu, C. H., & Fang, W. C. (2011). Combining the fuzzy analytic hierarchy process and the fuzzy Delphi method for evaluating flexible manufacturing systems. **Expert Systems with Applications**, 38(11), 14197-14205. https://doi.org/10.1007/s11135-010-9425-6

Yadgarzadeh, F. (2017). An analysis of job- and occupation-based components in curriculum design. **Higher Education Curriculum Studies,** 15(8), 135–178. https://dor.isc.ac/dor/20.1001.1.25382241.1396.8.15.6.2. [In Persian].

Yadgarzadeh, F. (2018). Identifying the components of professional responsibility among curriculum specialists**. Curriculum Studies Research**, 16(8), 199–223. https://doi.org/10.22099/jcr.2019.5124. [In Persian].

Yadgarzadeh, Gh., Fathi-Vajargah, K., Mehrmohammadi, M., & Arefi, M. (2013). Analysis of professional roles and activities of curriculum specialists. **Iranian Journal of Curriculum Studies**, 8(30). https://www.noormags.ir/view/fa/articlepage/1059884/. [In Persian].